SIECI NEURONOWE MLP DO KOMPENSACJI ODKSZTAŁCEŃ TERMICZNYCH ŚRUB TOCZNYCH OBRABIAREK CNC

IZABELA ROJEK
Uniwersytet Kazimierza Wielkiego w Bydgoszczy
MICHAŁ KOWAL, ROMAN STANIEK
Politechnika Poznańska

Streszczenie

W artykule przedstawiono jednokierunkowe wielowarstwowe sieci neuronowe ze wsteczną propagacją błędu (MLP) do kompensacji odkształceń termicznych śrub tocznych obrabiarek CNC. Potrzeba poprawy dokładności pozycjonowania serwonapędu stała się bodźcem do rozpoczęcia prac badawczych nad nową bezczujnikową metodą kompensacji odkształceń termicznych śrub tocznych, która umożliwi kompensację wydłużenia takiej śruby na podstawie danych historycznych. Sieci neuronowe opracowano z różną strukturą oraz parametrami uczenia. Dokonano porównania tych sieci. Miarą oceny modeli była skuteczność działania tych sieci. Modele te przetestowano na danych rzeczywistych.

Słowa kluczowe: kompensacja temperaturowa, śruba toczna, obrabiarka, sieć neuronowa

Wprowadzenie

Stałe dążenie do wzrostu dokładności i produktywności obrabiarek sterowanych numerycznie wymusza permanentny ich rozwój. Współczesne obrabiarki sterowane numerycznie stanowią wysoce zaawansowane układy mechatroniczne, w których powszechnie stosuje się zaawansowane technicznie układy sterowania o rozdzielczości pracy interpolatorów wyrażanej w nanometrach.

Silna konkurencja na rynku obrabiarek zmusiła w ostatnim czasie producentów do zainteresowania się segmentem obrabiarek ekonomicznych, w których dąży się do połączenia dużej dokładności i produktywności z relatywnie niższymi kosztami. Jednym z głównych elementów kosztotwórczych osi sterowanych numerycznie jest bezpośredni układ pomiarowy. Rezygnacja z takiego rozwiązania przyczynia się do wzrostu błędu pozycjonowania wynikającego z błędów łańcucha kinematycznego serwonapędu, a szczególnie odkształceń termicznych śruby tocznej.

Potrzeba poprawy dokładności pozycjonowania serwonapędu wyposażonego w tani pośredni układ pomiarowy stała się bodźcem do rozpoczęcia prac badawczych nad nową, innowacyjną, bezczujnikową metodą kompensacji odkształceń termicznych śrub tocznych, która umożliwi kompensację wydłużenia takiej śruby na podstawie danych historycznych. Takie rozwiązanie powinno umożliwić skuteczną kompensację zmian długości śruby bez potrzeby pomiaru jej wydłużenia jak również bez pomiaru temperatury. Wcześniejsze badania dotyczące bezczujnikowej metody kompensacji odkształceń termicznych śrub tocznych zostały opisane w pracach [2,3], a dotyczące technicznych zastosowań sieci neuronowych w pracach [4,5,6].

W artykule rozszerzono badania nad zastosowaniem sieci neuronowych MLP do kompensa-

cji odkształceń termicznych śrub tocznych obrabiarek CNC. Z opracowanych modeli sieci neuronowych zostały wybrane najlepsze, charakteryzujące się największą skutecznością działania.

1. Bezczujnikowa metoda kompensacji odkształceń termicznych śrub tocznych

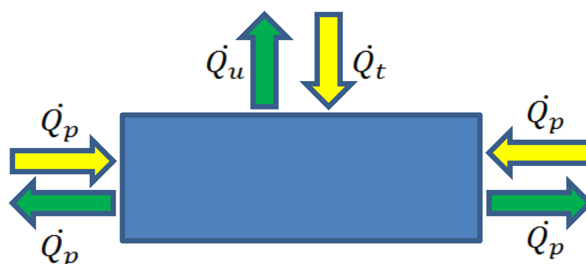
Analizując zagadnienie energii dyssypowanej w zespole śruba - nakrętka oraz węzłach łożyskowych na skutek tarcia, można przyjąć założenie upraszczające, mówiące, że ilość energii rozproszonej zależy od konstrukcji serwonapędu, a także warunków jego pracy, tj. prędkości kątowej i momentu obrotowego przenoszonego przez śrubę toczną. Słuszność tego założenia potwierdzają autorzy w pracach [1, 8, 10].

Istota nowej, proponowanej metody kompensacji odkształceń cieplnych śrub tocznych polega na użyciu informacji z układu sterowania i napędu obrabiarki, dotyczących aktualnej wartości prędkości obrotowej i momentu obrotowego. Informacje te, ze względu na wystarczające częstotliwości pomiarów stanowić będą podstawę do budowy modelu kompensacji termicznej śrub tocznych opartego na sztucznych sieciach neuronowych. Autorzy zamierzają udowodnić hipotezę, że analizując chwilową wartość momentu obrotowego oraz chwilową wartość prędkości obrotowej silnika można wyznaczyć z pewnym przybliżeniem ilość energii rozpraszanej w śrubie, która decyduje o jej wydłużeniu. W połączeniu z pomiarem temperatury otoczenia możliwe będzie skuteczne opisanie zjawiska konwekcji ciepła. Największą zaletą proponowanej metody jest całkowity brak czujników pomiaru temperatury i wydłużenia na badanym obiekcie.
Śrubę toczną można potraktować jako układ półzamknięty. Bilans energetyczny takiego układu przedstawia zależność (1):

$$\frac{dx}{dt} = p(t) - q(t), \qquad (1)$$

gdzie: p(t) - ilość energii dopływającej od układu w jednostce czasu, q(t) - ilość energii odpływającej od układu w jednostce czasu.

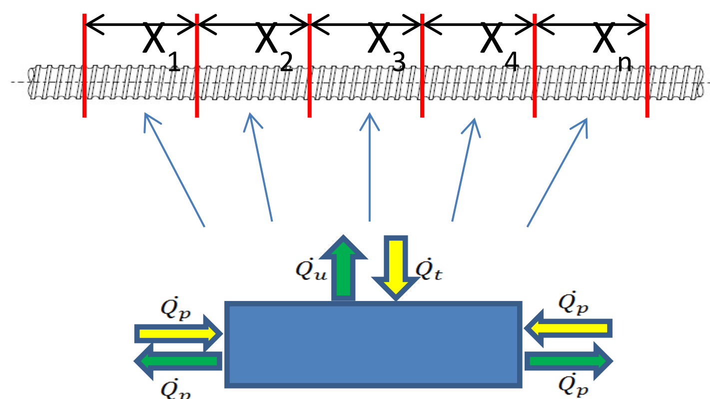
Można wyróżnić 3 podstawowe drogi przekazywania energii (rys. 1). Qt - energia doprowadzana do systemu na skutek tarcia zespołu śruba - nakrętka, Qu - energia odprowadzona z układu na drodze konwekcji oraz Qp - energia odprowadzana oraz zasilająca system z sąsiednich węzłów na drodze kondukcji.



Rysunek 1. Energia dostarczana oraz odprowadzana z systemu

Źródło: [3]

Ze względu na charakter pracy śruby tocznej w obrabiarkach sterowanych numerycznie wymaga się podziału śruby tocznej na odcinki elementarne (rys. 2). Wartość kompensacji wyznaczona zostaje w sposób indywidualny dla każdego z odcinków elementarnych umożliwiając tym samym skuteczna kompensację śruby tocznej. Model każdego odcinka elementarnego powinien uwzględniać założenia bilansu energetycznego śruby tocznej.



Rysunek. 2. Podział śruby na odcinki elementarne

Źródło: [3]

Proponowana metoda kompensacji w sposób ciągły analizuje prędkość oraz moment przenoszony przez śrubę toczną. Na podstawie wcześniej przeprowadzonego cyklu strojenia indywidualnego dla śruby tocznej, algorytm określa zmianę długości dla odcinka elementarnego w jednostce czasu. Każdy odcinek elementarny reprezentowany jest w formie elementu tablicy błędu skoku śruby, dostępnej w większości współczesnych układów sterowania. Zmianę długości odcinka elementarnego modyfikuje wartość kompensacji błędu skoku śruby, umożliwiając skuteczną kompensację odkształceń termicznych bez potrzeby ingerencji w wewnętrzne struktury interpolatorów, ograniczając błędy konturu obrabianej części. Ważne jest, aby przypisanie nowej wartości kompensacji błędu skoku śruby nie następowało w trakcie procesu skrawania. Skokowa zmiana wartości kompensacji wprowadzi błąd konturu widoczny na obrabianej powierzchni. Dobrą sposobnością do przypisania nowej wartości kompensacji staje się proces wymiany narzędzia. Proces ten odbywa się dostatecznie często, szczególnie w małych obrabiarkach, które charakteryzują się dużą dynamiką zmian błędu pozycjonowania na skutek zjawiska rozszerzalności termicznej śruby tocznej [3].

2. Kompensacja odkształceń termicznych śrub tocznych obrabiarek CNC

W artykule przedstawiono model opisujący zjawisko dyssypacji energii w zespole śruba - nakrętka na skutek tarcia Qt. Fragment zebranych danych doświadczalnych został pokazany w tabeli 1. Dane te zawierają prędkość, obciążenie oraz wydłużenie. Zakres prędkości zmienia się od 25 do 300 z krokiem 25.

Tabela 1. Fragment zebranych danych doświadczalnych

	F-25 mm/s			F-50 mm/s		
Obciążenie [Nm]	0,35931645	1,11408096	1,495940654	0,453932	1,202533	1,56081
Wydłużenie [um]	1,0767	1,2	1,62	1,9333	1,78	1,9143

Źródło: opracowanie własne

2.1. Tworzenie modelu sieci neuronowej

Wstępne przetwarzanie danych dla sieci neuronowej

Wstępne przetwarzanie danych odgrywa ważną rolę zarówno podczas uczenia, jak i testowania sieci neuronowych. Na tym etapie należy rozwiązać takie problemy jak właściwy dobór cech, ich selekcja czy wybór odpowiednich przykładów [7,9].

Identyfikacja struktury i parametrów wybranego modelu sieci

Identyfikacja struktury modelu, daje odpowiedź:

1. ile warstw zawiera sieć neuronowa (czy potrzebne są warstwy ukryte ?)
2. ile neuronów występuje w każdej warstwie ?
3. czy należy dołączyć dodatkowy neuron w celu lepszej stabilności sieci w trakcie uczenia (bias)?
4. jak dobrać parametry uczenia sieci neuronowej ?

Liczba warstw ukrytych oraz neuronów w tych warstwach mają istotny wpływ na jakość działania sieci warstwowej. Liczba neuronów ukrytych najczęściej dobierana jest eksperymentalnie. Wielokrotne powtarzanie procesu uczenia pozwala zaprojektować sieci dostatecznie duże, by mogły nauczyć się problemu, a jednocześnie na tyle małe, aby poprawnie generalizować [7,9].

Identyfikacja parametrów modelu polega na dobraniu wag połączeń między neuronowych. Wagi połączeń dobierane są tak długo, aż wartość błędu średniokwadratowego nie osiągnie minimalnej wartości, co pozwoli na zakończenie procesu uczenia.

Weryfikacja modelu sieci neuronowej

Weryfikacja modelu sieci polega na testowaniu, walidacji oraz korekcie modelu sieci neuronowej. **Testowanie modelu** sprawdza działanie sieci na danych mieszczących się w pliku testowym. Dane testowe to zbiór przypadków, które nigdy nie były używane do uczenia danej sieci. **Walidacja modelu** pozwala sprawdzić, czy dla nowych wartości wejściowych sieć poprawnie dobiera parametry wyjściowe. Walidacja sprawdza dokładność sieci neuronowej na podstawie nowego zestawu danych, które nie były wykorzystywane w procesie uczenia sieci. **Korekta modelu** polega na zmianie ilości neuronów w sieci, douczeniu sieci, jeśli sieć jest zbyt dokładnie nauczona, lub też zmianie liczby warstw ukrytych [7,9].

2.2. Utworzenie i wybór najlepszego modelu do kompensacji odkształceń w postaci sieci neuronowych typu MLP

Sieci MLP niezmiennie są najbardziej rozpowszechnionymi i uniwersalnymi sieciami neuronowymi stosowanymi do rozwiązywania różnych problemów.

Wejścia sieci zawierają prędkość i obciążenie. Wyjście sieci wskazuje wydłużenie śruby. Na rysunku 3 pokazano fragment danych, które posłużyły jako wejścia i wyjście sieci neuronowych. Struktura pliku testowego i walidacji jest taka sama. Plik uczący zawiera 70% przykładów, plik testowy 15%, a plik walidacyjny kolejne 15%. Liczba całkowita przykładów wyniosła 204. Sieci MLP zbudowane zostały z jedną warstwą ukrytą. Eksperymenty związane z tworzeniem modeli sieci neuronowych typu MLP były parametryzowane dwoma parametrami: liczbą neuronów w warstwie ukrytej oraz liczbą epok uczących. W eksperymencie parametr liczba neuronów w warstwie ukrytej przyjmował wartości od 3 do 30, natomiast drugi parametr liczba epok uczących przyjmował wartości od 4 do 300. Po zakończeniu każdego eksperymentu, przeprowadzone były testy, które dostarczały informacji na temat błędnych odwzorowań. Liczba neuronów w warstwie ukrytej została dobrana eksperymentalnie.

Sieci neuronowe są narzędziem nieliniowym, uczonym z reguły przez algorytmy iteracyjne. Do uczenia sieci MLP wykorzystano algorytm BFGS (*Broyden-Fletcher-Goldfarb-Shanno*). Jest to jeden z najbardziej efektywnych algorytmów uczenia sieci neuronowych. Np. zapis BFGS 4 oznacza, że optymalne rozwiązanie otrzymano w 4 iteracjach. Funkcja błędu jest używana do oceny aktualnej jakości sieci w procesie jej uczenia. Zastosowano funkcje błędu w postaci funkcji sumy kwadratów (SOS). W przypadku neuronów w warstwie ukrytej funkcja aktywacji jest typu liniowa, logistyczna, Tanh (tangens hiperboliczny) lub wykładnicza. Funkcją aktywacji neuronów wyjściowych jest funkcja liniowa, Tanh lub Softmax. Każdy z tych parametrów wpływa na skuteczność sieci neuronowych.

	dane_kompensacja_Qt		
	1 prędkość	2 obciążenie	3 **wydłużenie**
1	25	0,359316	1,0767
2	25	1,114081	1,2
3	25	1,495941	1,62
4	50	0,453932	1,9333
5	50	1,202533	1,78
6	50	1,56081	1,9143
7	75	0,522479	1,9314
8	75	1,247564	2,0564
9	75	1,61883	2,36
10	100	0,583087	2,025
11	100	1,273597	2,1643
12	100	1,653362	2,44
13	125	0,635402	2,3655
14	125	1,310963	2,6067
15	125	1,685973	2,55
16	150	0,691697	2,02
17	150	1,335204	2,6714
18	150	1,715891	2,88
19	175	0,70137	2,3291
20	175	1,366642	2,8327
21	175	1,741964	2,88
22	200	0,735158	2,5
23	200	1,389391	3,0868

Rysunek. 3. Fragment danych pliku uczącego

Źródło: opracowanie własne

Skuteczność sieci neuronowej została obliczona jako proporcja poprawnie zaklasyfikowanych przypadków w stosunku do wszystkich przypadków ze zbioru.

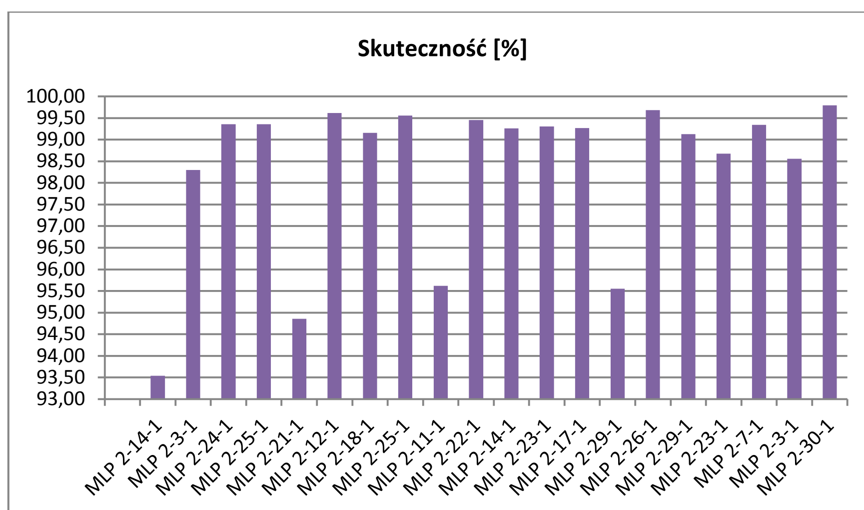
Tabela 2 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP. Skuteczność sieci wyrażona jest w %. W eksperymencie wybrano 20 najlepszych sieci neuronowych.

Na rysunku 4 pokazano wykres skuteczności sieci neuronowych typu MLP.

Tabela 2. Parametry sieci MLP

Id sieci	Nazwa sieci	Skuteczność [%]	Błąd	Algorytm uczenia	Aktywacja (ukryte)	Aktywacja (wyjściowe)
1	MLP 2-14-1	93,54	0,028715	BFGS 4	Liniowa	Tanh
2	MLP 2-3-1	98,30	0,007856	BFGS 269	Logistyczna	Sinus
3	MLP 2-24-1	99,36	0,002953	BFGS 90	Wykładnicza	Wykładnicza
4	MLP 2-25-1	99,36	0,003107	BFGS 74	Tanh	Wykładnicza
5	MLP 2-21-1	94,86	0,025768	BFGS 5	Liniowa	Logistyczna
6	**MLP 2-12-1**	**99,62**	**0,001799**	**BFGS 198**	**Tanh**	**Logistyczna**
7	MLP 2-18-1	99,16	0,003850	BFGS 61	Logistyczna	Liniowa
8	**MLP 2-25-1**	**99,56**	**0,002008**	**BFGS 168**	**Tanh**	**Logistyczna**
9	MLP 2-11-1	95,62	0,020222	BFGS 6	Liniowa	Sinus
10	MLP 2-22-1	99,46	0,002555	BFGS 135	Tanh	Sinus
11	MLP 2-14-1	99,26	0,003425	BFGS 71	Logistyczna	Sinus
12	MLP 2-23-1	99,30	0,003224	BFGS 82	Tanh	Liniowa
13	MLP 2-17-1	99,27	0,003317	BFGS 102	Wykładnicza	Logistyczna
14	MLP 2-29-1	95,56	0,020093	BFGS 4	Sinus	Liniowa
15	**MLP 2-26-1**	**99,69**	**0,001575**	**BFGS 224**	**Logistyczna**	**Logistyczna**
16	MLP 2-29-1	99,13	0,003982	BFGS 60	Logistyczna	Sinus
17	MLP 2-23-1	98,68	0,005907	BFGS 47	Wykładnicza	Liniowa
18	MLP 2-7-1	99,34	0,003155	BFGS 170	Tanh	Wykładnicza
19	MLP 2-3-1	98,56	0,006379	BFGS 69	Wykładnicza	Logistyczna
20	**MLP 2-30-1**	**99,80**	**0,001034**	**BFGS 214**	**Tanh**	**Tanh**

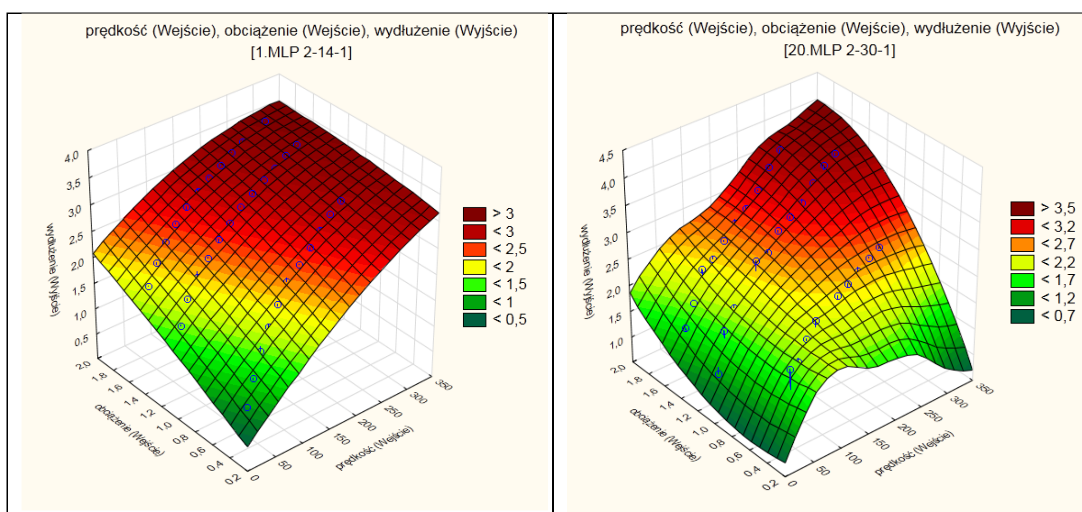
Źródło: opracowanie własne



Rysunek. 4. Wykres skuteczności sieci neuronowych typu MLP

Źródło: opracowanie własne

Odwzorowanie wydłużenia od prędkości i obciążenia dla najgorszej (2-14-1) i najlepszej sieci MLP (2-30-1) pokazano na rysunku 5.



Rysunek. 5. Odwzorowanie wydłużenia od prędkości i obciążenia

Źródło: opracowanie własne

Tabela 3 pokazuje działanie sieci neuronowych dla nowych danych podanych na wejście sieci. Sprawdzenie działania sieci następuje poprzez porównanie danych na wyjściu sieci ze wzorem podanym w ostatniej kolumnie tabeli.

Tabela 3. Porównanie odpowiedzi sieci neuronowych MLP z wzorcem

	Odpowiedź sieci neuronowych MLP				wzorzec
nr przy-padku	Odpowiedź sieci 2-12-1 wydłużenie	Odpowiedź sieci 2-25-1 wydłużenie	Odpowiedź sieci 2-26-1 wydłużenie	Odpowiedź sieci 2-30-1 wydłużenie	wydłużenie
1	1,076700	1,078548	1,076700	1,071544	1,0767
2	1,195251	1,175794	1,076700	1,198616	1,2
3	1,626304	1,600214	1,604923	1,624843	1,62
4	1,937131	1,941960	1,922858	1,956220	1,9333
5	1,834182	1,715990	1,790983	1,794332	1,78
6	1,928674	1,985470	1,909729	1,903512	1,9143
7	2,009720	1,924096	1,929314	1,884443	1,9314
8	2,008559	2,081872	2,050084	2,064367	2,0564
9	2,316277	2,225538	2,397194	2,378045	2,36
10	1,998555	2,072250	2,091071	2,110829	2,025
11	2,192395	2,244408	2,173049	2,130489	2,1643
12	2,470237	2,446279	2,364714	2,412183	2,44
13	2,206773	2,222639	2,253232	2,270702	2,3655
14	2,543246	2,547003	2,496789	2,629720	2,6067
15	2,622285	2,628713	2,585652	2,617705	2,55
16	2,178734	2,007747	2,083766	2,044294	2,02
17	2,671820	2,666902	2,727820	2,651219	2,6714
18	2,793982	2,796456	2,851777	2,799556	2,88
19	2,312556	2,474885	2,399539	2,410303	2,3291
20	2,886005	2,880162	2,947815	2,916500	2,8327
21	2,962375	2,980260	2,915480	2,931773	2,88
22	2,514337	2,518207	2,517697	2,480794	2,5
23	3,159132	2,991872	3,057763	3,031724	3,0868
24	3,740000	3,736303	3,738195	3,736847	3,74

Źródło: opracowanie własne

Najlepszą siecią MLP o skuteczności 99,80% okazała się sieć **MLP 2-30-1** z funkcją błędów liczoną przy pomocy funkcji SOS, funkcją aktywacji Tanh w warstwie ukrytej i funkcją aktywacji Tanh w warstwie wyjściowej. Trochę gorsze okazały się sieć MLP 2-12-1 (99,62%), MLP 2-25-1 (99,56%) oraz MLP 2-26-1 (99,69%). Wadą przy uczeniu tych sieci był długi czas uczenia. Jest to pokazane jako liczba iteracji w tabeli 1 przy algorytmie BFGS.

4. Podsumowanie

Wykorzystanie sieci neuronowych umożliwia utworzenie komputerowego systemu wspomagania decyzji, który w sposób automatyczny pozyskuje wiedzę i ma właściwość adaptacji. Jest to szczególnie ważne przy opracowywaniu systemu wspomagania decyzji dla złożonych systemów technicznych, w których następują ciągłe zmiany, jedne podprocesy zależą od innych, wiele czynników zależy jeden od drugiego i każda zmiana systemu powoduje kolejne zmiany.

Korzyści ze stosowania sieci neuronowych wielokrotnie przekraczają pracochłonność ich tworzenia. W rzeczywistości najdłuższym etapem procesu ich tworzenia jest zgromadzenie i przygotowanie danych źródłowych, chociaż poprzez automatyczne gromadzenie danych również ten etap ulega skróceniu. Zastosowanie właściwych metod sztucznej inteligencji do tworzenia modeli oraz samo tworzenie modeli, oczywiście po opracowaniu odpowiednich procedur komputerowych, w najdłuższych przypadkach zajmuje kilka do kilkunastu minut.

Przeprowadzone badania wykazały użyteczność sieci neuronowych oraz ich dużą skuteczność do predykcyjnej kompensacji odkształceń termicznych śrub tocznych obrabiarek CNC.

Bibliografia

[1] Harris T. A., *Rolling Bearing Analysis*, Wiley & Sons, New York 1991.
[2] Kowal M., Staniek R., *Compensation system for thermal deformation of ball screws*, Proceedings of the 12th Biennial Conference on Engineering Systems Design and Analysis, ESDA 20469, Copenhagen 2014.
[3] Kowal M., *Sensorless compensation system for thermal deformations of ball screws in machine tools drives*, Archives of Mechanical Technology and Materials, 36, 1-6, 2016.
[4] Rojek I., *Classifier Models in Intelligent CAPP Systems*, w K.A. Cyran i in. (Eds.), Advances in Intelligent and Soft Computing, 59, 311–319, Springer-Verlag, Berlin Heidelberg 2009.
[5] Rojek I., *Neural networks as performance improvement models in intelligent CAPP systems*, Control and Cybernetics, 39(1), 55–68, 2010.
[6] Rojek I., *Technological Process Planning by the Use of Neural Networks*, Artificial Intelligence for Engineering Design, Analysis and Manufacturing, doi:10.1017/S0890060416000147, 2016.
[7] Rutkowski L., Metody i techniki sztucznej inteligencji, WTN, Warszawa 2006.
[8] *Solution for heating of ball screw and environmental engineering*, World Manufacturing Engineering and Market, 3, 65–67, 2004.
[9] Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa, 1993.
[10] Verl A., Frey S., *Correlation between feed velocity and preloading in ball screw drives*, Ann. CIRP, 59(2), 429–432, 2010.

Studies & Proceedings of Polish Association for Knowledge Management
Nr 79, 2016

MLP NEURAL NETWORKS
FOR COMPENSATION OF THERMAL DEFORMATIONS OF
BALL SCREWS OF CNC MACHINES

Summary

The article presents the unidirectional multilayer neural network with error back-propagation for compensation of thermal deformations of ball screws of CNC machines. The need to improve the accuracy of positioning servo-drive has become the impetus to start research on new sensorless compensation method of thermal deformation of ball screw, which allows compensation of elongation of the screws on the basis of historical data. Neural networks have been developed with a different structures and parameters of learning. These networks were compared. The effectiveness of these networks was a measure of models evaluation. These models have been tested on real data.

Keywords: thermal compensation, ball screw, machine tool, neural network

Izabela Rojek
Instytut Mechaniki i Informatyki Stosowanej
Wydział Matematyki, Fizyki i Techniki
Uniwersytet Kazimierza Wielkiego
ul. Chodkiewicza 30, 85-064 Bydgoszcz
e-mail: izarojek@ukw.edu.pl

Michał Kowal
Roman Staniek
Instytut Technologii Mechanicznej
Wydział Budowy Maszyn i Zarządzania
Politechnika Poznańska
ul. Piotrowo 3, 61-131 Poznań
e-mail: michal.kowal@put.poznan.pl
roman.staniek@put.poznan.pl